

**PRIORITY
DOCUMENT**

SUBMITTED OR TRANSMITTED IN
COMPLIANCE WITH RULE 17.1(a) OR (b)



Bescheinigung

REC'D	22 JAN 1999
WIPO	PCT

Die Max-Planck-Gesellschaft zur Förderung der Wissen-
schaften e.V. in München/Deutschland und die Firma
GMD-First in Berlin/Deutschland haben eine Patentanmel-
dung unter der Bezeichnung

"Verfahren zur Erfassung zeitabhängiger Moden
dynamischer Systeme"

am 15. September 1997 beim Deutschen Patent- und Markenamt
eingereicht.

Der Firmenname und der Sitz der Mitanmelderin GMD-First
wurden berichtet in: GMD - Forschungszentrum Informations-
technik GmbH in Sankt Augustin/Deutschland.

Die angehefteten Stücke sind eine richtige und genaue
Wiedergabe der ursprünglichen Unterlagen dieser Patent-
anmeldung.

Die Anmeldung hat im Deutschen Patent- und Markenamt vor-
läufig die Symbole G 05 B, G 07 C und A 61 B der Interna-
tionalen Patentklassifikation erhalten.

München, den 18. Dezember 1998
Deutsches Patent- und Markenamt

Der Präsident
Im Auftrag

Aktenzeichen: 197 40 565.7

v. Bezold & Sozien

Tel.: (089) 52 40 01
Fax: (089) 52 68 98
e-mail: sombez@t-online.de
ID/VAT DE 129730028

Patentanwälte
Brienner Str. 52
D-80333 München

v. Bezold & Sozien, Brienner Str. 52 · D-80333 München

Dr. Dieter v. Bezold
Dipl. Ing. Peter Schütz
Dipl. Ing. Wolfgang Heusler
Dr. Oliver Hertz
Europäische Patentanwälte
European Patent Attorneys
Mandataires Européens
Zugelassen / admitted OHIM

14472 Hz

Max-Planck-Gesellschaft
zur Förderung der Wissenschaften e. V.
Hofgartenstraße 2
80539 München

GMD-First
Rudower Chaussee 5
12489 Berlin

Verfahren zur Erfassung zeitabhängiger Moden dynamischer Systeme

Zusammenfassung

Bei einem Verfahren zur Erfassung der Moden eines dynamischen Systems mit einer Vielzahl von Moden, die jeweils einen Satz $\alpha(t)$ charakteristischer Systemparameter besitzen, wird eine Zeitreihe mindestens einer Systemvariablen $x(t)$ einer Modellierung wie z. B. einer Schaltsegmentierung unterzogen, die dazu eingerichtet ist, in jedem Zeitabschnitt einer vorbestimmten Mindestlänge für jede Systemvariable $x(t)$ ein vorbestimmtes Vorhersagemodell wie z. B. ein neuronales Netzwerk für eine entsprechende Systemmode zu erfassen, wobei nach der Modellierung der Zeitreihe eine Driftsegmentierung erfolgt, bei der in jedem Zeitabschnitt, in dem das System von einer ersten Systemmode zu einer zweiten Systemmode übergeht, eine Folge von gemischten Vorhersagemodellen erfaßt wird, die durch eine lineare, paarweise Überlagerung der Vorhersagemodelle der zwei Systemmoden gegeben ist.

Verfahren zur Erfassung zeitabhängiger Moden
dynamischer Systeme

Beschreibung

Die Erfindung betrifft ein Verfahren zur Erfassung dynamischer Systeme, die durch im Zeitverlauf nichtstationäre Systemparameter charakterisierbar sind, insbesondere ein Verfahren zur Segmentierung von Zeitreihen von Meßgrößen (Variablen) dynamischer Systeme und zur Identifizierung der die Segmente charakterisierenden Systemparameter (Moden).

Unter einem dynamischen System wird hier insbesondere jede Erscheinung verstanden, deren Zeitverlauf durch eine diskrete Abbildung vom Typ

$$x(t+1) = f_{\alpha(t)}(\alpha(t)) \quad (0.1)$$

darstellbar ist. Es werden jedoch auch Systeme mit mehreren (z. B. zwei) simultan aufgenommenen Zeitreihen x , y gemäß

$$y(t+\tau) = f_{\alpha(t)}(x(t)) \quad (0.2)$$

betrachtet. Dabei bezeichnen $\alpha(t)$ einen Satz charakteristischer Systemparameter, x einen Zustand, der im allgemeinen einen Vektor in einem mehrdimensionalen Zustandsraum bildet, und y einen zeitlich verschobenen Zustand. Der Zustandsraum wird von Variablen aufgespannt, die z. B. physikalische, chemische, biologische, medizinische, geologische, geometrische, numerische und/oder prozeßtechnische Größen sein können.

Die Anzahl der Systemvariablen, die zusammen mit der Dynamik f das System beschreiben, entspricht der Dimension des

Zustandsraumes. Hier werden Systeme betrachtet, deren Parameter α ebenfalls zeitlich veränderlich sein können. Ein gegebenes System mit zeitlich unveränderlichen Parametern α wird im folgenden auch als Mode bezeichnet.

Beobachtbare oder meßbare Systemvariablen (Meßgrößen) bilden erfaßbare Zeitreihen oder Datenströme, die für die jeweilige Abfolge von Systemmoden charakteristisch sind. Sind die Systemparameter innerhalb der Zeitreihen über bestimmte Zeitabschnitte (Segmente) unveränderlich, so kann die Zeitreihe entsprechend den jeweils bestehenden Systemmoden unterteilt werden (Segmentierung) und jedes Segment einer Systemmode zugeordnet werden (Identifizierung).

Viele Vorgänge in der Natur wie auch bei technischen Anwendungen würden sich dann vorhersagen und/oder kontrollieren lassen, wenn die ihnen zugrundeliegenden dynamischen Prozesse mathematisch modelliert werden können. Die Analyse und Charakterisierung praktisch gegebener dynamischer Systeme wird oft dadurch erschwert, daß sich die Systemmoden während der Beobachtung ändern. Beispiele hierfür sind allmähliche Veränderungen, die sich in Drifts oder Trends der Systemparameter widerspiegeln, oder auch spontane oder abrupte Veränderungen in der Dynamik komplexer Systeme, etwa wenn sich Konfigurationen spontan oder von außen getrieben plötzlich ändern.

Ein Beispiel für ein betrachtetes System ist die Erzeugung von Sprachsignalen im Mund-Rachen-Raum, bei der das System ständig seine Konfiguration und somit seine Mode ändert. Es besteht ein starkes Interesse daran, die Moden zu erfassen und zu identifizieren, die einem beobachteten Zeitverlauf einer Variablen (im Beispiel: Luftdruckschwankungen) zugrundeliegen, auch um verbesserte Vorhersagen über das betrachtete System treffen oder dieses besser kontrollieren zu können.

Prinzipiell können dynamische Systeme anhand vom gemessenen Signalen analysiert werden und es sind Reihe von Methoden bekannt, aus Zeitreihen Modelle zu gewinnen, die sich für die Vorhersage und eine Kontrolle des Systemverhaltens eignen. So ist bekannt, daß sich der Zustand eines dynamischen Systems durch Erfassung der Zeitabhängigkeit beobachtbarer Meßgrößen modellieren läßt. Diese Modellierung erfolgt gemäß einem ersten Ansatz durch eine Rekonstruktion des Zustandsraumes mittels sogenannter Zeit-Verzögerungs-Koordinaten, wie es z. B. von N. H. Packard et al. in "Physical Review Letters" (Bd. 45, 1980, S. 712 ff.) beschrieben ist. Auf der Basis einer solchen Rekonstruktion läßt sich dann nur ein einziges (globales) Modell f für die Dynamik finden. Die globale Rekonstruktion des Systems ist ferner nachteilig, da bei Anwendungen für vieldimensionale Systeme eine Vielzahl von Eingangsgrößen als Randbedingungen vorab bekannt sein müssen und/oder aufgrund der hohen Dimensionalität das System sich praktisch nicht mehr schätzen (erfassen, abbilden) läßt und/oder ein übermäßig hoher, nicht praktikabler Rechenaufwand entsteht.

Außerdem ist dieses Verfahren für den Fall zeitlich veränderlicher Parameter allgemein nicht anwendbar. Die Analyse und Modellierung von dynamischen Signalen wird jedoch häufig dadurch erschwert, daß die zugrundeliegenden Systeme sich in der Zeit in wesentlichen Parametern verändern. Beispiele sind z. B. Signale aus der Medizin, bei denen ein Organ wie das Herz oder das Gehirn viele dynamische Moden hat, die sich abwechseln, oder etwa den Sprachsignalen, bei denen das erzeugende System, der Mund-Rachen-Raum, in der Zeit offensichtlich verschiedene Konfigurationen durchläuft.

Gemäß einem weiteren Ansatz ist daher aus der Publikation von K. Pawelzik, J. Kohlmorgen und K.-R. Müller in "Neural Computation" (Bd. 8, 1996, S. 340 ff.) bekannt, Datenströme entsprechend zunächst unbekannten, zeitlich wechselnden

Systemmoden durch Simulierung mit mehreren, untereinander in Konkurrenz stehenden Modellen zu segmentieren. Die Modelle werden bevorzugt durch neuronale Netzwerke gebildet, die jeweils für eine Dynamik charakteristisch sind und nach vorbestimmten Trainingsregeln um die Beschreibung der einzelnen Punkte des Datenstroms konkurrieren.

Mit dieser Methode gelingt es, eine Zeitreihe in Abschnitte quasistationärer Dynamik zu zerlegen und simultan Modelle für diese System-Moden aus den Zeitreihen zu identifizieren.

Die Segmentierung gemäß K. Pawelzik et al., zu der unten Einzelheiten angegeben werden, erlaubt die Zuordnung von Segmenten zu bestimmten Systemdynamiken oder -moden und führt zu einer Erfassung des Datenstroms als Vorgang mit einem diskreten Schalten (sog. "switching") zwischen den Moden. Diese Beschreibung der Parameterdynamik komplexer Systeme stellt zwar gegenüber der o. a. globalen Modellierung hinsichtlich der Genauigkeit und der Segmentierung verschiedener Systemzustände einen Fortschritt dar. Allerdings kann der Übergang zwischen verschiedenen Systemzuständen nicht ausreichend beschrieben werden. Es hat sich insbesondere bei der Analyse realer Systeme z. B. bei medizinischen Anwendungen gezeigt, daß die Segmentierung auf bestimmte Fälle mit möglichst klaren Modenunterschieden und geringem Rauschen beschränkt, allgemein jedoch bei zeitlichen Veränderungen der erzeugenden Systeme unzuverlässig ist.

Solche zeitlichen Veränderungen der erzeugenden Systeme machen die beobachtbaren Signale nichtstationär und führen dazu, daß sich die Systeme im allgemeinen nicht mehr durch einheitliche Modelle beschreiben lassen. Erfolgen diese Veränderungen der Systeme plötzlich, so spricht man von Sprungprozessen.

Die Aufgabe der Erfindung ist es, verbesserte Verfahren zur Erfassung der Moden dynamischer Systeme mit nichtstationären

Systemparametern anzugeben, mit denen die Beschränkungen herkömmlicher Verfahren überwunden werden können und die es insbesondere ermöglichen, automatisch mit praktikablem Bearbeitungsaufwand und hoher Zuverlässigkeit Segmentierungen und Identifizierungen von Zeitreihen mit einer erhöhten Zahl von Einzelheiten vorzunehmen.

Diese Aufgabe wird durch das Verfahren mit den Merkmalen gemäß den Patentanspruch 1 gelöst. Vorteilhafte Ausführungsformen der Erfindung ergeben sich aus den abhängigen Ansprüchen.

Die Erfindung basiert auf der Idee, Übergänge zwischen verschiedenen Moden eines dynamischen Systems als Zwischenmoden des Systems aufzufassen, die paarweise lineare Interpolationen der Ausgangs- bzw. Endmoden des Übergangs darstellen. Die betrachteten dynamischen Systeme gehen eher allmählich von einer Mode in die andere über, statt abrupt zwischen Moden zu schalten. Die Erfindung zielt darauf ab, solche Übergänge zwischen dynamischen Moden in Signalen und die Moden zu identifizieren.

Es wird daher bei einem Verfahren zur Erfassung der Moden dynamischer Systeme z. B. nach einer Schaltsegmentierung einer Zeitreihe mindestens einer der Systemvariablen $x(t)$ des Systems eine Driftsegmentierung vorgenommen, bei der in jedem Zeitabschnitt, in dem das System von einer ersten Systemmode s_i zu einer zweiten Systemmode s_j übergeht, eine Folge von gemischten Vorhersagemodellen g_i erfaßt wird, die durch eine lineare, paarweise Überlagerung der Vorhersagemodelle $f_{i,j}$, der zwei Systemmoden $s_{i,j}$ gegeben ist.

Gegenstand der Erfindung ist auch eine Vorrichtung zur Erfassung eines dynamischen Systems mit einer Vielzahl von Moden s_i mit jeweils charakteristischen Systemparametern $\alpha(t)$. Die Vorrichtung enthält eine Einrichtung zur Aufnahme einer Zeitreihe mindestens einer der Systemvariablen $x(t)$ des

Systems, eine Schaltsegmentierungseinrichtung, die dazu eingerichtet ist, in jedem Zeitabschnitt einer vorbestimmten Mindestlänge für die Systemvariablen $x(t)$ ein vorbestimmtes Vorhersagemodell f_i für eine entsprechende Systemmode s_i zu erfassen, und eine Driftsegmentierungseinrichtung, mit der in jedem Zeitabschnitt, in dem das System von einer ersten Systemmode s_i zu einer zweiten Systemmode s_j übergeht, eine Folge von gemischten Vorhersagemodellen g_i erfaßt wird. Die erfindungsgemäße Vorrichtung kann ferner Einrichtungen zur Einstellung von Interpolations- und Segmentierungsparametern, Vergleicherschaltungen zur Verarbeitung von Vorhersagefehlern von Vorhersagemodellen, Anzeige- und Signalisierungseinrichtungen und Speichereinrichtungen enthalten. Die erfindungsgemäße Vorrichtung kann ein Monitor für physiologische Daten oder physikalische oder chemische Prozeßparameter sein.

Mit der Erfindung steht ein Instrument zur Verfügung, welches ein großes Anwendungspotential in vielen medizinischen, wissenschaftlichen und technischen Bereichen hat. Mit der Segmentierung von Signalen und einer entsprechenden Identifizierung der zugrundeliegenden Dynamik eröffnen sich neue Möglichkeiten der Vorhersage und der Kontrolle auch wesentlich nichtstationärer Systeme.

Anwendungen der Erfindung haben gezeigt, daß sich kontinuierliche Übergänge zwischen Systemmoden sicher identifizieren ließen und daß die zugrundeliegenden Dynamiken durch die Modelle mit einer Präzision beschreibbar sind, die in vielen Fällen eine Vorhersage des Systemverhaltens ermöglicht. Mit der Erfindung lassen sich in vielen Fällen nichtstationärer Prozesse Modelle identifizieren, die sich auch für eine Kontrolle der Prozesse eignen, die ohne eine Berücksichtigung der Nichtstationarität nicht möglich waren.

Ausführungsformen und weitere Vorteile der Erfindung werden im folgenden unter Bezug auf die beigefügten Zeichnungen beschrieben. Es zeigen:

Fig. 1: Kurvendarstellungen zur Illustration eines ersten Segmentierungsschrittes des erfindungsgemäßen Verfahrens;

Fig. 2: Kurvendarstellungen zur Illustration eines weiteren Segmentierungsschrittes des erfindungsgemäßen Verfahrens

Fig. 3: Kurvendarstellungen zur Segmentierung von Blutregulierungsdaten nach dem erfindungsgemäßen Verfahren; und

Fig. 4: Kurvendarstellungen zur Segmentierung von EEG-Daten nach dem erfindungsgemäßen Verfahren.

Im folgenden werden zunächst Einzelheiten der Erfindung unter Bezug auf die Figuren 1 und 2 und anschließend praktische Anwendungsbeispiele erläutert. Es ist dem Fachmann ersichtlich, daß die Erfindung nicht auf die Anwendungsbeispiele beschränkt ist, sondern entsprechend auch in anderen Gebieten angewendet werden kann, wie sie beispielhaft weiter unten aufgeführt sind.

(1) Erfassung von Driftübergängen in nichtstationären Zeitreihen

Erfindungsgemäß werden nichtstationäre Zeitreihen mit einer zweischrittigen Prozedur erfaßt, bei der zunächst eine geeignete Modellierung und anschließend eine sogenannte Driftsegmentierung erfolgt. Die Modellierung ist dazu eingerichtet, in jedem Zeitabschnitt einer vorbestimmten Mindestlänge für jeden Systemparameter ein vorbestimmtes Vorhersagemodell für eine entsprechende Systemmode zu erfassen. Hierzu erfolgt vorzugsweise eine herkömmliche

Schaltsegmentierung, wie sie beispielsweise aus der Publikation von K. Pawelzik et al. in "Neural Computation" (Bd. 8, 1996, S. 340 ff.) bekannt ist. Die Modellierung kann aber auch durch eine andere, in Bezug auf die gewonnene Systeminformation zur Schaltsegmentierung äquivalente Prozedur erfolgen, die an eine konkrete Anwendung z. B. bei bekannten reinen Moden oder Randbedingungen angepaßt ist.

Die Schritte der Schalt- und Driftsegmentierung werden im folgenden näher erläutert. Hinsichtlich der Schaltsegmentierung wird hiermit der Inhalt der Publikation von K. Pawelzik et al. ausdrücklich vollständig in die vorliegende Beschreibung einbezogen.

(i) Schritt 1 (Schaltsegmentierung)

Die Schaltsegmentierung dient der Ermittlung charakteristischer Prediktoren, die zur Beschreibung der Systemmoden geeignet sind. Die Schaltsegmentierung kann entweder an einer Trainings-Zeitreihe oder an der zu untersuchenden Zeitreihe durchgeführt werden. In beiden Fällen können die ermittelten Vorhersagemodelle oder Prediktoren für weitere, unbekannte Zeitreihen verwendet werden.

Es wird ein dynamisches System mit einer endlichen Zahl N unterschiedlicher Moden betrachtet. Für die j -te Mode ist ein Wert (allg.: Vektor oder Satz) $\alpha_j(t)$ eines beobachtbaren Systemparameters charakteristisch, der jeweils mit einer Funktion $f_{i(t)}$ ($i = 1, \dots, N$) aus einem Satz von N Funktionen f modelliert werden soll. Es wird die Zeitreihe $\{x_t\} = x_j(t)$ der Systemvariablen betrachtet und zeitabhängig jeweils nach der Funktion $f_{i(t)}$ gesucht, für die $\{y_t\} = y_j(t) = f_{i(t)}(x_j(t))$ eine neue Zeitreihe vorherzusagender Punkte $y_j(t)$ darstellt, die in Bezug auf die Systemmoden qualitativ die selben Eigenschaften hat wie $\{x_t\}$. Durch den Wechsel der Modellfunktion f im Zeitverlauf wird die Schaltsegmentierung gefunden, die die

Zeitreihe $\{x_t\}$ entsprechend der wechselnden Systemmoden unterteilt.

Die Funktionen f werden als Prediktoren (oder: Vorhersagemodelle, Expertenfunktionen) aus einem Satz von Netzwerken mit veränderlichen Parametern durch ein geeignetes Trainingsprogramm abgeleitet, bei dem simultan sowohl die Parameter der Netzwerke als auch die Segmentierung ermittelt werden. Der Begriff "Netzwerk" wird hier für alle möglichen geeigneten Modellfunktionen verwendet, also vorzugsweise für neuronale Netzwerke, aber auch z. B. für Polynome oder lineare Funktionsapproximationen. Die optimale Wahl eines neuronalen Netzwerkes erfolgt in Abhängigkeit von der spezifischen Anwendung. Es werden vorzugsweise Netzwerke mit einer schnellen Lernfähigkeit, wie z. B. sogenannte RBF-Netzwerke (Radial Basis Function Network) vom Moody-Darke-Typ verwendet.

Das Training erfolgt unter der Voraussetzung, daß die Systemmoden nicht mit jedem Zeitschritt wechseln, sondern eine geringere Schaltrate aufweisen, so daß eine Systemmode über mehrere Zeitschritte erhalten bleibt. Die angenommene Grenze der Schaltrate bzw. Anzahl der Zeitschritte, über die eine Systemmode erhalten bleibt, ist zunächst ein freier Eingangsparameter und kann anwendungsabhängig in geeigneter Weise beispielsweise in Abhängigkeit vorgegebener Erfahrungswerte oder nach einer Parameteranpassungsstrategie ausgewählt werden. Bei der Parameteranpassungsstrategie kann vorgesehen sein, für die Schaltrate einen Ausgangswert vorzugeben und mit diesem einen Vorhersagefehler (siehe unten) zu ermitteln. Falls die Schaltrate zu hoch oder zu niedrig gewählt ist, führt eine entsprechende Über- oder Unterspezialisierung zu einem zu hohen Vorhersagefehler. Im weiteren Verlauf der Anpassung kann dann die Schaltrate optimiert werden, bis der mittlere Vorhersagefehler unterhalb vorbestimmter Grenzen liegt.

Das Training erfolgt durch Maximierung der Wahrscheinlichkeit W , daß der Satz von Netzwerken die Zeitreihe $\{x_t\}$ erzeugen würde. Es handelt sich um ein Training mit konkurrierendem Lernen (engl.: "competitive learning"), wie es im einzelnen in der Abhandlung "Introduction to the theory of neural computation" von J. Hertz et al. (Addison-Wesley Publishing Company 1991, insb. Kap. 9: "Unsupervised competitive learning") beschrieben wird. Aus dieser Abhandlung ist die anwendungsabhängige Implementierung eines solchen Trainings ableitbar. Die Trainingsregel des konkurrierenden Lernens auf der Grundlage des beim Lernen auftretenden Fehlers ist gemäß (1) darstellbar.

$$\frac{\partial \log W}{\partial f_i} \propto \left[\frac{e^{-\beta(y-f_i)^2}}{\sum_j e^{-\beta(y-f_j)^2}} \right] (y-f_i) \quad (1)$$

Diese Trainingsregel stellt sicher, daß die Lerngeschwindigkeit (Verbesserung der Parameter) für die Funktionen f mit geringstem Abstand zum Zielwert y am höchsten ist.

Figur 1 zeigt das Ergebnis der Schaltsegmentierung am Beispiel der Analyse einer chaotischen Zeitreihe $\{x_t\}$ mit $x_{t+1} = f(x_t)$ zwischen den vier Moden:

$$\begin{aligned} f_1(x) &= 4x(1-x) \text{ für } x \in [0, 1] \\ f_2(x) &= f_1(f_1(x)) \\ f_3(x) &= 2x \text{ für } x \in [0, 0.5] \text{ bzw.} \\ f_3(x) &= 2(1-x) \text{ für } x \in [0.5, 1] \\ f_4(x) &= f_3(f_3(x)) \end{aligned}$$

Für die ersten 50 Zeitschritte wird mit einem Startwert $x_0 = 0.5289$ zunächst f_1 angewendet. Anschließend erfolgt ein Übergang (Einzelheiten siehe (ii)) zur Mode f_2 , die nach Schritt 100 bis Schritt 150 stationär wird. Entsprechend wird

ab Schritt 200 bzw. Schritt 300 jeweils für 50 Schritte die Mode f_3 bzw. f_4 eingenommen. Danach erfolgt der Rückübergang auf f_1 . Figur 1a zeigt einen Ausschnitt (Schritte 300 bis 450) des Zeitverlaufs der Zeitreihe $\{x_t\}$ mit $x_{t+1} = f(x_t)$.

Die Segmentierung der ersten 450 Zeitschritte mit 6 Prediktoren f_i , $i = 1, \dots, 6$ (RBF-Netzwerke vom Moody-Darken-Typ) ist in Figur 1b dargestellt. Das Training ergibt eine Spezialisierung von vier der Prediktoren (6, 2, 4, 3) jeweils auf eine der o. a. vier Moden. Die stationären Bereiche liegen bei den Intervallen $[0, 50]$ und $[400, 450]$ (f_1), $[100, 150]$ (f_2), $[200, 250]$ (f_3) und $[300, 350]$ (f_4). Die übrigen zwei Prediktoren (3, 5) haben sich auf die Übergangsbereiche zwischen den Moden spezialisiert. Dies zeigt den Nachteil der herkömmlichen Schaltsegmentierung, bei der im Fall von Übergängen der entsprechende Zeitbereich ohne adäquate Beschreibung mehrfach unterteilt wird.

Anstelle des hier beschriebenen sog. "Hard competition"-Trainings, bei dem bei einem Trainingsschritt jeweils nur ein Vorhersagemodell optimiert wird ("winner takes all") kann auch vorgesehen sein, den Grad der Konkurrenz im Rahmen eines sog. "Soft competition"-Trainings zu verändern, wie es im einzelnen in der Publikation von K. Pawelzik et al. beschrieben ist.

(ii) Schritt 2 (Driftsegmentierung)

Beim zweiten Schritt werden die Übergänge (sog. Driften, nicht-abruptes Übergehen, gleitendes Wechseln) zwischen den Systemmoden berücksichtigt. Mit der Erfindung wurde als wichtige Voraussetzung für die Driftsegmentierung herausgefunden, daß der Übergang von einer ersten Systemmode direkt in eine zweite Systemmode und nicht über eine dritte Systemmode erfolgt. Das Driften zwischen Systemmoden wird somit wie folgt durch eine Überlagerung von (oder paarweise

lineare Interpolation zwischen) genau zwei Moden modelliert. Dabei treten gemischte, ggf. abgestufte Zwischenmoden auf, die jedoch nicht eigene (reine) Systemmoden sind.

Es wird ein Satz von P reinen Systemmoden, die jeweils durch ein Netzwerk $k(s)$, $s \in P$, repräsentiert werden, und ein Satz von M gemischten Systemmoden betrachtet, die jeweils durch eine lineare Überlagerung von zwei Netzwerken $i(s)$ und $j(s)$, $s \in M$, repräsentiert werden. Das Modellnetzwerk g_s für eine gegebene Mode $s \in S$, $S = P \cup M$ wird gemäß Gleichung (2) dargestellt.

$$g_s(\vec{x}_t) = \begin{cases} f_{k(s)}(\vec{x}_t) & \text{für } s \in P \\ a(s)f_{i(s)}(\vec{x}_t) + b(s)f_{j(s)}(\vec{x}_t) & \text{für } s \in M \end{cases} \quad (2)$$

In (2) ist \vec{x} der Vektor $(x_t, x_{t-\tau}, \dots, x_{t-(m-1)\tau})$ der Zeitverzögerungskordinaten der Zeitreihe $\{x_t\}$ und $f_{i,j}$ sind Prediktoren, die gemäß der o. a. Schaltsegmentierung ermittelt wurden. Dabei ist m eine Einbettungsdimension und τ der Verzögerungsparameter der Einbettung. Die Einbettungsdimension ist die Dimension des Phasenraumes, in dem das System betrachtet wird und in dem die Modelle operieren.

Für jede gemischte Systemmode sind zwei Parameter a, b zusammen mit zwei Netzwerkindices i, j charakteristisch. Zur Vereinfachung des Rechenaufwandes wird die Zahl der gemischten Moden begrenzt. Mit $0 < a(s) < 1$ und $b(s) = 1 - a(s)$ wird eine endliche Zahl von Werten $a(s)$ definiert. Zur weiteren Vereinfachung werden gleiche Abstände zwischen den Werten $a(s)$ gemäß Gleichung (3) gewählt.

$$\bar{a}_r = \frac{r}{R+1} \quad \text{mit } r = 1, \dots, R \quad (3)$$

R entspricht der Anzahl der zugelassenen Zwischenmoden und wird auch als Auflösung oder Abstufung der Interpolation

zwischen den reinen Moden bezeichnet. Die Auflösung R kann einen beliebigen Wert annehmen, wird jedoch anwendungsabhängig zur Erzielung einer optimalen Systembeschreibung (insbesondere bei stark verrauschten Vorgängen) und praktikabler Rechenzeiten insbesondere unter Berücksichtigung der oben genannten Schaltrate ausreichend niedrig gewählt. Bei praktischen Anwendungen (siehe unten) kann vorgesehen sein, daß die Auflösung R manuell von einem Bediener oder automatisch von einem Stellkreis in Abhängigkeit von einem vorliegenden Analyseergebnis und einem Vergleich mit einem vorgegebenen Schwellwert gewählt werden.

Die Gesamtzahl der gemischten Moden beträgt bei einer gegebenen Auflösung R zwischen jeweils zwei Netzen $|M| = R \cdot N \cdot (N-1)/2$. Bei dem o. a. Beispiel beträgt somit bei $N = 8$ reinen Moden und einer Auflösung $R = 32$ und Gesamtzahl der gemischten Moden $|M| = 896$. Zur Bestimmung der Gesamtzahl der Systemmoden kommen noch die 8 reinen Moden hinzu.

Die Driftsegmentierung umfaßt nun die Suche nach einer Segmentierung mit den reinen und gemischten Systemmoden (a , b , R), die in Bezug auf den Vorhersagefehler der Moden der gesamten Zeitreihe optimiert ist. Die Prediktoren werden so ausgewählt, daß jedem Element der Zeitreihe einer der Moden aus der Gesamtzahl der Systemmoden zugeordnet werden kann. Der Vorhersagefehler ist die Abweichung einer Prediktorenvorhersage vom tatsächlichen Element der zu untersuchenden Zeitreihe. Für die zu untersuchende Zeitreihe, die nicht mehr unbedingt die Trainings-Zeitreihe ist, mit der bei der Schaltsegmentierung die angepaßten Netzwerke oder Prediktoren ermittelt wurden, wird für jeden Zeitschritt mit jedem der Prediktoren eine Vorhersage ermittelt, woraus sich eine zeitabhängige Matrix der Prediktorenvorhersagen ergibt, aus der ein mittlerer Vorhersagefehler für willkürlich gewählte Segmentierungen ableitbar ist. Die Segmentierungen

mit dem geringsten Vorhersagefehler ist die gesuchte Driftsegmentierung.

Die Suche nach der Segmentierung mit dem geringsten Vorhersagefehler kann mit jeder geeigneten Such- oder Iterationstechnik erfolgen. Vorzugsweise wird eine dynamische Programmieretechnik gewählt, die äquivalent zum Viterbi-Algorithmus für HM-Modelle (sog. Hidden Markov Models) ist. Einzelheiten hierzu sind beispielsweise in der Publikation "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition" von L. R. Rabiner in "Readings in Speech Recognition" (Hrsg. A. Waibel et al., San Mateo, Morgan Kaufmann, 1990, S. 267-296) beschrieben. Die Driftsegmentierung ist im Rahmen der HM-Modelle die wahrscheinlichste Modensequenz, die die zu untersuchende Zeitreihe erzeugt haben könnte. Als Nebenbedingung wird dabei die Möglichkeit der Moden-Änderungen über die T-Funktion (siehe unten) eingeschränkt.

Das Ziel der Anpassung ist die Angabe einer optimalen Sequenz von Netzwerken bzw. linearen Mischungen aus diesen. Eine Sequenz ist optimal, wenn die sogenannte Energie- oder Cost-Funktion C^* der Vorhersage minimiert ist. Die Cost-Funktion C^* setzt sich aus der Summe der quadratischen Fehler der Vorhersage und den Cost-Funktionen der Modenübergänge der Sequenz zusammen. Die Ableitung der Cost-Funktion C^* jeweils zwischen zwei Zeitpunkten t_0 und t_{\max} erfolgt induktiv, indem zunächst von einer Start-Cost-Funktion gemäß Gleichung (4) ausgegangen wird.

$$C_s(t_0) = \varepsilon_s(t_0) \quad (4)$$

wobei

$$\varepsilon_s(t) = (x_t - g_s(\vec{x}_{t-1}))^2 \quad (5)$$

der quadratischen Fehler der Vorhersage der reinen oder gemischten Moden g ist.

Für den Induktionsschritt von $t - 1$ auf t wird die Cost-Funktion gemäß Gleichung (6) für alle $s \in S$ berechnet:

$$C_s(t) = \varepsilon_s(t) + \min_{s \in S} \{C_s(t-1) + T(\hat{s}, s)\}, \quad t=t_0+1, \dots, t_{\max} \quad (10)$$

Dabei ist $T(\hat{s}, s)$ die Cost-Funktion des Übergangs von einer Mode \hat{s} zu einer Mode s .

Die optimale (minimale) Cost-Funktion C^* ist dann:

$$C^* = \min_{s \in S} \{C_s(t_{\max})\} \quad (11)$$

Die Funktion T entspricht bei den HM-Modellen den Übergangswahrscheinlichkeiten und kann anwendungsabhängig geeignet gewählt werden. Es kann beispielsweise vorgesehen sein, abrupte Schaltübergänge und gleitendes Driften zwischen zwei Netzen zuzulassen und alle anderen Übergänge durch $T = \infty$ auszuschließen.

Die Driftsegmentierung ergibt sich aus der ermittelten optimalen Sequenz von Netzwerken bzw. linearen Mischungen aus diesen, indem die Moden, die C^* ergeben, zurückverfolgt und in Abhängigkeit von der Zeit erfaßt werden.

Im Anschluß an die Driftsegmentierung kann sich ein zusätzlicher Schritt der Reduzierung der Zahl der zur Modellierung verwendeten Netzwerke anschließen, der im einzelnen unten beschrieben wird.

Abschließend findet eine Identifizierung der segmentierten Moden statt, indem jedem Prediktor oder Vorhersagemodell die zugehörige Systemmode zugeordnet wird. Diese Identifizierung erfolgt anwendungsabhängig.

Das Ergebnis der Driftsegmentierung im Fall der oben unter Bezug auf Figur 1 erläuterten chaotischen Zeitreihe $\{x_t\}$ mit vier Moden wird im folgenden unter Bezug auf Figur 2 beschrieben. Die Driftsegmentierung umfaßt die Suche nach einem Verlauf $a(t)$, der einen speziellen Pfad zwischen den reinen Moden liefert, für den der Vorhersagefehler der gesamten Zeitreihe optimiert ist.

Jeweils nach den ersten 50 Zeitschritte mit der Mode gemäß f_1 erfolgt für 50 Schritte ein zeitlinearer Übergang in die Mode gemäß f_2 . Der Übergang ist ein zeitabhängiges Driften gemäß den Gleichungen (12):

$$f(\vec{x}_t) = (1 - a(t))f_1(\vec{x}_t) + a(t)f_2(\vec{x}_t)$$

mit

$$a(t) = \frac{t - t_a}{t_b - t_a} \quad t_a = 50, \quad t_b = 100 \quad (12)$$

Entsprechende Übergänge finden nach dem 150., 250. und 350. Schritt für jeweils 50 Schritte statt.

In Figur 2 ist die Besetzung der jeweiligen Moden entsprechend den ermittelten Netzwerken in Abhängigkeit von der Zeit (Zeitschritte [1200, 2400]) dargestellt. Aus Übersichtlichkeitsgründen sind die Übergangs- oder Driftbereiche entsprechend ihren Zeitgrenzen und Ausgangs- bzw. Endmoden in Rahmen dargestellt, in denen der jeweilige Driftverlauf zwischen den Moden gepunktet ist. Figur 2a zeigt bei einer Auflösung $R = 32$ (siehe Gleichung (3)) Übergänge wie z. B. bei den Zeitschritten 1350 bis 1400 zwischen den Netzen 2 und 4. Die Übergänge sind wie gemäß Gleichung (12) erwartet linear. Bei einer geringeren Auflösung von $R = 3$ ergibt sich die in Figur 2b dargestellte Segmentierung. Abweichend vom linearen Driftverlauf sind die gepunkteten Übergänge stufenförmig. Dennoch ist die Darstellung auch bei der geringeren Auflösung eine adequate Beschreibung des

dynamischen Verhaltens des Systems, wie der Vergleich der zeitlichen Lage der Moden und des Driftens zeigt.

(2) Anwendungsbeispiele für die Erfassung von Driftübergängen

(i) Blutzellenregulation im menschlichen Körper

Die Blutzellenregulation im menschlichen Körper stellt ein hochdimensionales chaotisches System dar, das durch die Mackey-Glass-Verzögerungs-Differentialgleichung (13) (siehe auch in der o. a. Abhandlung von J. Hertz et al.) beschrieben werden kann.

$$\frac{dx(t)}{dt} = -0.1x(t) + \frac{0.2x(t-t_d)}{1+x(t-t_d)^{10}} \quad (13)$$

Erfindungsgemäß können Zeitreihen von physiologischen Parametern, die für die Menge der roten Blutkörper charakteristisch sind, anwendungsabhängig segmentiert werden. Die Funktionsfähigkeit der Segmentierung wird im folgenden beispielhaft erläutert.

Bei Vorgabe von zwei Moden A und B, die sich jeweils durch verschiedene Verzögerungsparameter $t_d = 17$ bzw. $t_d = 23$

unterscheiden, erfolgt mit einer Abtast-Zeitschrittgröße $\tau = 6$ nach 100 Schritten zunächst ein Übergang von A nach B. Der Übergang dauert 100 Schritte und ist eine Überlagerung der Gleichung (13) mit den beiden Verzögerungsparameter t_d während der Integration von Gleichung (13). Die Überlagerung wird mit einem exponentiellen Driftparameter a (siehe Gleichung (2)) gemäß Gleichung (14) erzeugt.

$$a(t) = \exp\left(\frac{-4t}{100}\right) \quad , \quad t = 1, \dots, 100 \quad (14)$$

In der Folge wiederholen sich alle 100 Schritte stationäre Moden A oder B bzw. die jeweiligen Übergänge. Für jeden

Rück-Übergang nach einem Driftübergang wird ein schaltartiges Umspringen angenommen. Figur 3a zeigt die entsprechende Zeitreihe über 300 Schritte. Die Driftsegmentierung mit sechs Prediktoren auf der Grundlage von RBF-Netzwerken mit jeweils 40 Basisfunktionen, einem Einbettungsparameter $m = 6$ und dem Verzögerungsparameter $\tau = 1$ (siehe Gleichung (2)) ergibt das in Figur 3b gezeigte Bild. Es zeigt sich die erwartete Segmentierung der Zeitreihe in stationäre Moden und Driftübergänge.

Allerdings zeigt sich, daß sich jeweils 2 Netzwerke auf eine Mode spezialisiert haben ($2, 3 \Rightarrow$ Mode A, $5, 6 \Rightarrow$ Mode B). In einer solchen Situation kann es erfindungsgemäß vorgesehen sein, den zusätzlichen Schritt der Reduzierung der Zahl der zur Modellierung verwendeten Netzwerke vorzusehen.

Der Reduzierungsschritt umfaßt eine sequentielle Reduzierung der Netzwerkzahl, jeweils verbunden mit einer Bestimmung des mittleren Vorhersagefehlers. Die Reduzierung (Abzug von Redundanznetzwerken) wird beendet, falls eine weitere Verringerung der Netzwerkzahl eine signifikante Erhöhung des Vorhersagefehlers bedeutet. Figur 3c zeigt das Ergebnis einer solchen Reduzierung. Der mittlere quadratische Fehler RMSE bleibt bei der Reduzierung um ein, zwei, drei und vier Netzwerke jeweils konstant, wohingegen ein starker Anstieg für den Fall auftritt, daß nur noch mit einem Netzwerk modelliert wird. Dies bedeutet, daß das System optimal mit einer Zahl von Netzwerken modelliert wird, die gleich der Gesamtzahl von betrachteten Netzwerken, vermindert um die Zahl von Redundanznetzwerken ist.

Die adequaten Modellnetze werden dann erhalten, indem der RMSE-Wert für jede Netz-Kombination mit reduzierter Netzzahl berechnet wird. Die Netz-Kombination mit dem geringsten RMSE-Wert umfaßt die gesuchten Modellnetzwerke oder Prediktoren. Figur 3d zeigt die Driftsegmentierung nach dem

Reduzierungsschritt. Demnach beschreiben die übrig gebliebenen Prediktoren 2 und 5 das System vollständig.

(ii) Schlafdatenerfassung

Eine weitere Anwendung der Erfindung liegt im Bereich der Analyse physiologischer Daten, die für den Ablauf von Schlaf- und Wachmoden von Lebewesen charakteristisch sind. Als Grundlage für sich anschließende Prozeduren zur Erfassung von Schlafstörungen können Zeitreihen z. B. von EEG-Daten segmentiert werden.

Figur 4a zeigt im Vergleich die Ergebnisse einer herkömmlichen Schaltsegmentierung (oben), einer Driftsegmentierung (Mitte) und einer "manuellen" Segmentierung (unten) eines medizinischen Fachmannes (Schlaafforscher) auf der Grundlage von Erfahrungswerten am Beispiel eines Nachmittagsschlafes eines gesunden Menschen. Die Schalt- und Driftsegmentierungen erfolgen mit acht Netzwerken (net1 ... net8) an Einkanal-EEG-Daten $x(t)$ (Figur 4b). In Figur 4a sind wie bei Figur 2 aus Übersichtlichkeitsgründen Rahmen gezogen, die bei den Driftmoden verdeutlichen, zwischen welchen Netzen interpoliert wird. Die gepunktete Linie im Inneren der Rahmen zeigt den jeweils tatsächlichen Verlauf. Die manuelle Segmentierung basiert auf der Beobachtung von physiologischen Signalen (z. B. EEG, EOG, ECG, Puls, Blutdruck, Atmung, Augenbewegungen). Die Moden W1, W2 bezeichnen zwei Wachmoden mit offenen bzw. geschlossenen Augen und die Moden S1, S2 jeweils Schlafzustände. "n.a." und "art." beziehen sich auf nicht in Betracht gezogene Zustände bzw. Artefakte.

Die Schaltsegmentierung zeigt ein vergleichsweise undifferenziertes Bild, das nur grob mit den übrigen Beobachtungen konsistent ist. So tritt beispielsweise ein Einschlafvorgang in allen drei Fällen bei $t \approx 7000$ auf. Die

Driftsegmentierung ergibt jedoch mehrere Driftübergänge, die zusätzliche Einzelheiten des Schlafverhaltens darstellen. Der "manuell" beobachtete Schlafbeginn zur Zeit $t \approx 4000$ wird durch einen exponentiellen Driftübergang von Netz net7 (Wachmoden-Prediktor) zum Netz net4 (Schlafmoden-Prediktor) repräsentiert. Das Aufwachen setzt bei $t \approx 9000$ durch ein leichtes Rückdriften zum Netz net7 ein, das bis zum Erreichen des "manuell" ermittelten Aufwachpunktes $t \approx 9500$ gehalten wird. In dieser Situation erfolgt eine plötzliche Änderung des Wichtungsfaktors, so daß das Netz net7 eine größere Wichtung erhält. Nach $t \approx 9800$ (Augen offen) besteht eine Mischung der beiden Wachmoden-Prediktoren net7 und net2.

(iii) Weitere Anwendungen und Vorteile

Figur 4a zeigt, daß mit dem erfindungsgemäßen Verfahren automatisch detaillierte Segmentierungen erzielt werden können, die bislang nur durch die Beobachtung komplexer Merkmalsbilder auf der Grundlage breiter Erfahrungen und Intuitionen zugänglich waren. Dieser Vorteil ist nicht nur in der Medizin, sondern auch in anderen Gebieten nutzbar, in denen große Datenmengen bei der Beschreibung komplexer dynamischer Systeme anfallen. Derartige Gebiete sind die physikalische, chemische und/oder biologische Verfahrenstechnik, die Geologie, Meteorologie, -Klimatologie, die Spracherfassung u. dgl..

Erfindungsgemäße Verfahren haben die folgenden Vorteile. Das betrachtete System kann hochdimensional sein (10 oder mehr Dimensionen). Die Erfindung erlaubt eine Reduzierung der Komplexität eines solchen Systems durch Betrachtung von niedrigerdimensionalen Moden und von wechselnden Übergängen zwischen diesen. Der Einsatz von Vorhersagemodellen für die

Segmentierung ist invariant gegen Änderungen der Amplitude erfaßter Signale.

Die Anwendung der Erfindung für die Vorhersage oder Kontrolle eines Systems erfolgt derart, daß zunächst wie oben beschrieben aus der vergangenen Beobachtung und der Kenntnis der aktuellen Moden der IST-Zustand des Systems erfaßt wird, der ggf. eine Mischung entsprechend dem Ergebnis der Driftsegmentierung darstellt. Der IST-Zustand entspricht einem dynamischen System f . Die Vorhersage bedeutet, daß das System f auf den momentanen Zustand x angewendet wird und sich daraus die Vorhersage für den unmittelbar folgenden Zustand y ergibt. Die Kontrolle bedeutet, daß aus dem IST-Zustand die Abweichung von einem SOLL-Zustand ermittelt und aus der Abweichung eine geeignete Regelstrategie abgeleitet wird.

Der Vorteil der Vorhersage und Kontrolle besteht darin, daß in komplexen Systemen (z. B. bei der Erfassung chemischer Reaktionen in einem Reaktor), die ggf. die Messung lediglich weniger Meßgrößen erlauben, die für sich allein aufgrund von Mehrdeutigkeiten oder wegen systemimmanenten Verzögerungen keine direkten Rückschlüsse auf den Systemzustand und ggf. bestehende gemischte Zustände erlauben, dennoch detaillierte Informationen über das System abgeleitet werden können. So kann bei dem Beispiel mit einer chemischen Reaktion aus der erfindungsgemäßen Erfassung beispielsweise der makroskopischer thermodynamischer Zustandsgrößen eine optimale Regelstrategie abgeleitet werden, die die Dosierung bestimmter Reaktionspartner umfaßt.

Patentansprüche

1. Verfahren zur Erfassung der Moden eines dynamischen Systems mit einer Vielzahl von Moden s_i , die jeweils einen Satz $\alpha(t)$ charakteristischer Systemparameter besitzen, wobei eine Zeitreihe mindestens einer Systemvariablen $x(t)$ einer Modellierung unterzogen wird, die dazu eingerichtet ist, in jedem Zeitabschnitt einer vorbestimmten Mindestlänge für jede Systemvariable $x(t)$ ein vorbestimmtes Vorhersagemodell f_i für eine entsprechende Systemmode s_i zu erfassen,

dadurch gekennzeichnet, daß

nach der Modellierung der Zeitreihe eine Driftsegmentierung erfolgt, bei der in jedem Zeitabschnitt, in dem das System von einer ersten Systemmode s_i zu einer zweiten Systemmode s_j übergeht, eine Folge von gemischten Vorhersagemodellen g_i erfaßt wird, die durch eine lineare, paarweise Überlagerung der Vorhersagemodelle $f_{i,j}$ der zwei Systemmoden $s_{i,j}$ gegeben ist.

2. Verfahren gemäß Anspruch 1, bei dem die Modellierung eine Schaltsegmentierung ist.

3. Verfahren gemäß Anspruch 2, bei dem die Schaltsegmentierung durch Simulierung einer Trainings-Zeitreihe des Systems oder der zu untersuchenden Zeitreihe mit mehreren, untereinander in Konkurrenz stehenden Vorhersagemodellen erfolgt.

4. Verfahren gemäß Anspruch 3, bei dem die Vorhersagemodelle durch neuronale Netzwerke oder andere Modelle zur Schätzung von Funktionen gebildet werden, die jeweils für eine Mode s charakteristisch sind und nach vorbestimmten Trainingsregeln um die Beschreibung der einzelnen Elemente der Zeitreihe konkurrieren.

5 Verfahren gemäß einem der Ansprüche 1 bis 4, bei dem die Folge gemischter Systemmoden g_i aus den Vorhersagemodelle $f_{i,j}$ und Interpolationsparametern a , b gemäß $g_i = a(s)f_{i(s)}(x) + b(s)f_{j(s)}(x)$ ermittelt wird.

6. Verfahren gemäß Anspruch 5, bei dem die Interpolationsparameter gemäß $0 < a(s) < 1$ und $b(s) = 1 - a(s)$ gewählt sind.

7. Verfahren gemäß Anspruch 6, bei dem die Werte $a(s)$ auf eine bestimmte Auflösungszahl R beschränkt und/oder äquidistant sind.

8. Verfahren gemäß einem der vorhergehenden Ansprüche, bei dem die Folge gemischter Vorhersagemodelle g_i erfaßt wird, indem für jeden Zeitschritt mit jedem der möglichen Vorhersagemodelle jeweils eine Vorhersage ermittelt wird, woraus sich eine zeitabhängige Vorhersagematrix ergibt, aus der ein mittlerer Vorhersagefehler für willkürlich gewählte Segmentierungen ableitbar ist, wobei die gesuchte Folge gemischter Vorhersagemodelle g_i die Segmentierung mit dem geringsten Vorhersagefehler bzw. der maximalen Wahrscheinlichkeit ist.

9. Verfahren gemäß Anspruch 8, bei dem die Suche nach der Segmentierung mit dem geringsten Vorhersagefehler mit einer dynamische Programmieretechnik erfolgt, die äquivalent zum Viterbi-Algorithmus für Hidden-Markov-Modelle ist, wobei eine optimale Sequenz von Vorhersagemodellen unter Verwendung einer minimierten Cost-Funktion C^* der Vorhersage ermittelt wird und die Segmentierung induktiv aus der Sequenz von Vorhersagemodelle abgeleitet wird.

10. Verfahren gemäß einem der vorhergehenden Ansprüche, bei dem nach der Driftsegmentierung ein zusätzlicher Schritt der

Reduzierung der Zahl der zur Modellierung verwendeten Vorhersagemodelle erfolgt, bei dem die Zahl der Vorhersagemodelle sequentiell jeweils verbunden mit einer Bestimmung des mittleren Vorhersagefehlers so weit reduziert wird, daß eine weitere Verringerung der Zahl der Vorhersagemodelle eine Erhöhung des Vorhersagefehlers bedeutet.

11. Verfahren gemäß einem der vorhergehenden Ansprüche, bei dem die Zeitreihe mindestens einer der Systemvariablen $x(t)$ eine Zeitreihe von physiologischen Parametern umfaßt, die mit der Mackey-Glass-Verzögerungs-Differentialgleichung

$$\frac{dx(t)}{dt} = -0.1x(t) + \frac{0.2x(t-t_d)}{1+x(t-t_d)^{10}}$$

beschrieben wird.

12. Verfahren gemäß einem der Ansprüche 1 bis 11, bei dem die Zeitreihe mindestens einer der Systemvariablen $x(t)$ eine Zeitreihe von physiologischen Parametern umfaßt, die für den Ablauf von Schlaf- und Wachmoden charakteristisch sind.

13. Verfahren gemäß Anspruch 12, bei dem die physiologischen Parameter EEG-Signale umfassen.

14. Verfahren gemäß einem der Ansprüche 1 bis 10, bei dem die Zeitreihe mindestens einer der Systemvariablen $x(t)$ eine Zeitreihe von Sprachsignalen umfaßt.





Fig. 1

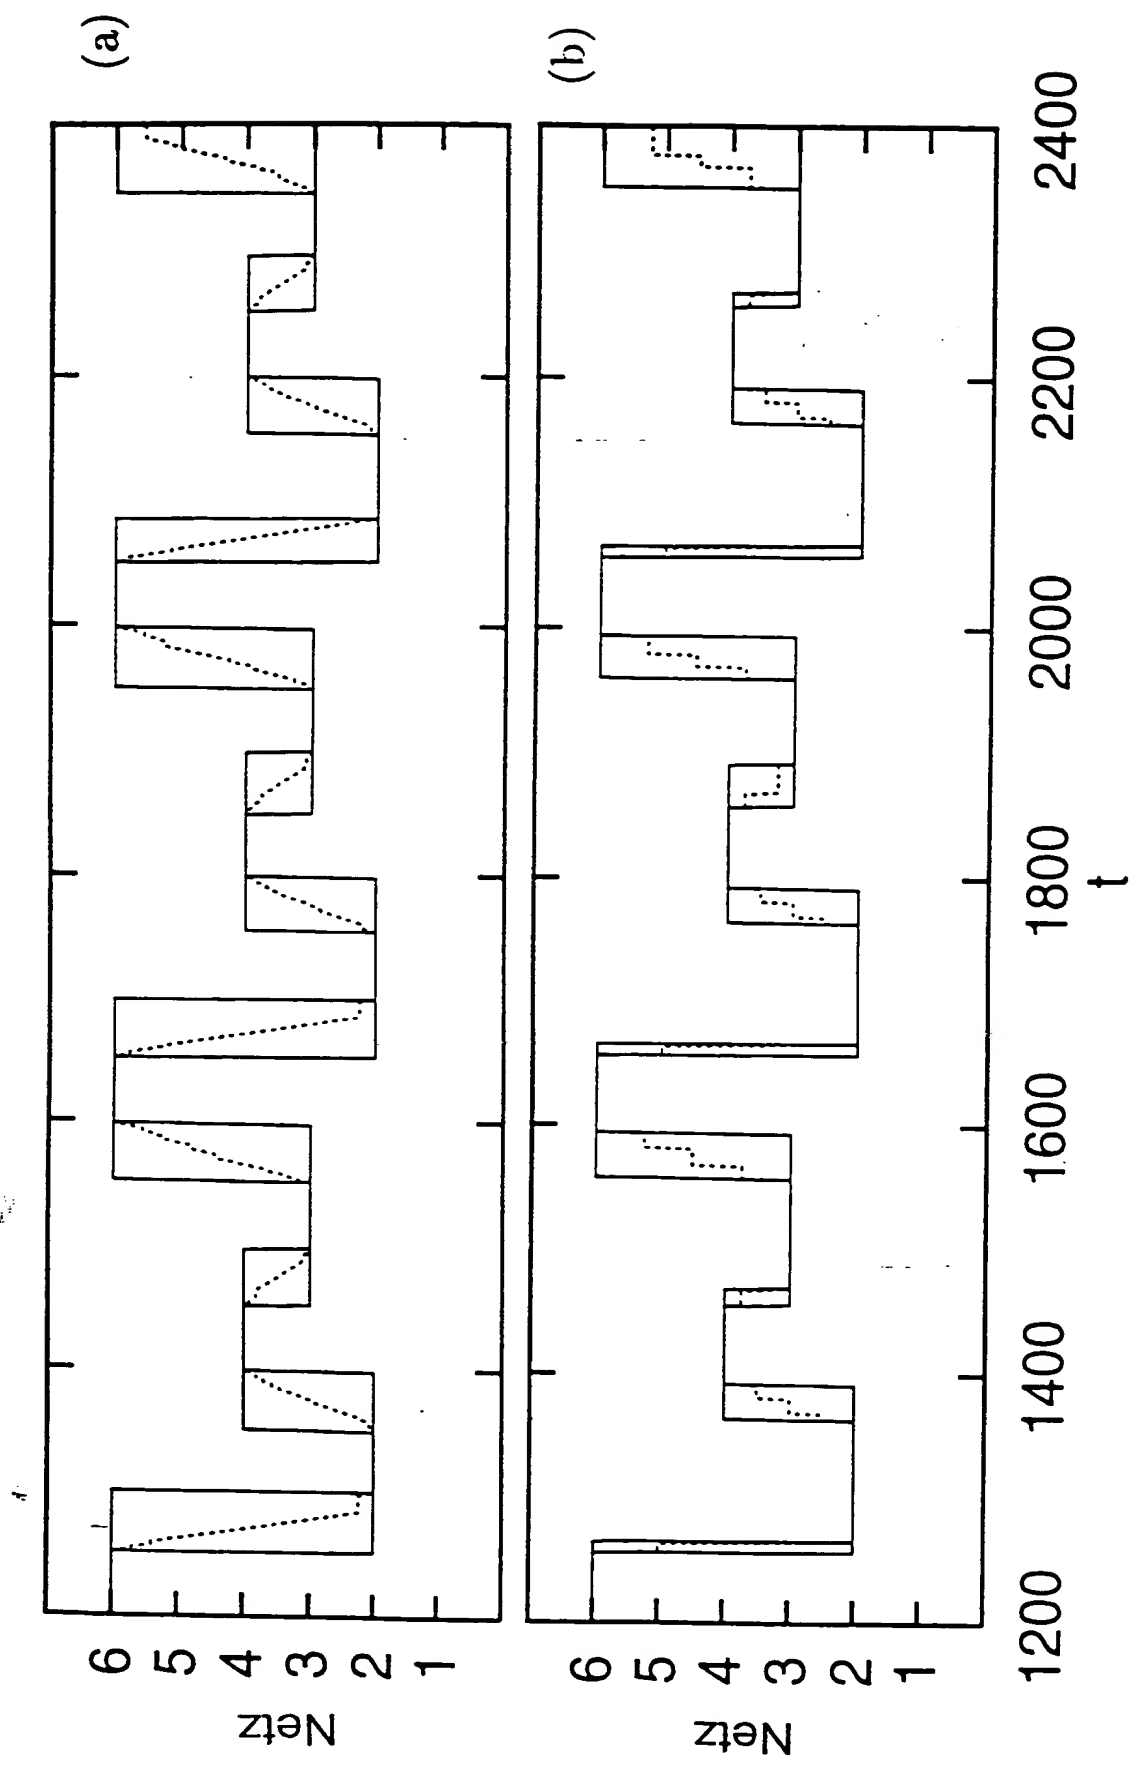


Fig. 2







Fig. 3




Fig. 4